一种基于膨胀残差宽度网络的模态分析模型框架[1]

曾培健[1]　林楠铠[1]　白期风[1]　李顺[1]　阳爱民[*,1,2]　林江豪[*,3]

[1]（广东工业大学计算机学院 广州 510000）

[2]（岭南师范学院　湛江 524000）

[3]（广东工业大学自动化学院　广州 510000）

摘要：

本文基于膨胀残差卷积宽度网络提出一种模态分析的策略。在模态分析中，大规模结构或复杂系统的振动分析通常需要处理大量的数据和复杂的计算。采用膨胀残差卷积宽度架构可以降低网络的参数量和计算复杂度，减轻计算负担，提高分析的效率。膨胀残差卷积宽度网络应用于模态分析任务能够提升振动特征的提取能力、改善模态识别的准确性、增强结构损伤检测的敏感性，并且具有较高的计算效率和参数效率。实验结果表明，我们的模型在模态分析预测的回归任务中取得了优异的成绩。

关键词： 模态分析　深度学习　宽度学习　效率

A model framework for modal analysis based on dilated residual broad networks

Peijian Zeng[1]　Nankai Lin[1]　Qifen Bai[1]　Shun Li[1]　Aimin Yang[*,1,2]　Jianghao Lin[*,3]

[1](School of Computer science Guangdong University of Technology,Guangzhou 510000,China)

[2] (School of Computer Science and Intelligence Education Lingnan Normal University,Zhanjiang 524000,China)

[3] (School of Automation Guangdong University of Technology,Guangzhou 510000,China)

Abstract:

This paper proposes a modal analysis strategy based on dilated residual convolutional broad network. In modal analysis, vibration analysis of large-scale structures or complex systems usually requires processing large amounts of data and complex calculations.The dilated residual convolution width architecture can reduce the number of parameters and computational complexity of the network, reduce the computational burden, and improve the efficiency of analysis.The dilated residual convolutional broad network applied to modal analysis tasks can improve the extraction ability of vibration features, improve the accuracy of modal identification, and enhance the sensitivity of structural damage detection, and has high computational efficiency and parameter

[1] 本文系广东省重点领域研发计划项目“国产化结构动力学 CAE 软件”(项目编号:2021B0101190004)的研究成果之一。

efficiency. The experimental results show that our model achieves excellent performance in the regression task of modal analysis prediction.
Keywords：Modal Analysis Deep Learning Broad Learning Efficiency

1. 引言

1.1 模态分析的背景

振动模态是弹性结构固有的、整体的特性。通过模态分析方法搞清楚了结构物在某一易受影响的频率范围内的各阶主要模态的特性，就可以预言结构在此频段内在外部或内部各种振源作用下产生的实际振动响应。因此，模态分析是结构动态设计及设备故障诊断的重要方法。

机器、建筑物、航天航空飞行器、船舶、汽车等的实际振动模态各不相同。模态分析提供了研究各类振动特性的一条有效途径。首先，将结构物在静止状态下进行人为激振，通过测量激振力与响应并进行双通道快速傅里叶变换（FFT）分析，得到任意两点之间的机械导纳函数（传递函数）。用模态分析理论通过对试验导纳函数的曲线拟合，识别出结构物的模态参数，从而建立起结构物的模态模型。根据模态叠加原理，在已知各种载荷时间历程的情况下，就可以预言结构物的实际振动的响应历程或响应谱。

近十多年来，由于计算机技术、FFT 分析仪、高速数据采集系统以及振动传感器、激励器等技术的发展，试验模态分析得到了很快的发展，受到了机械、电力、建筑、水利、航空、航天等许多产业部门的高度重视。已有多种档次、各种原理的模态分析硬件与软件问世。

模态分析求解的运动控制方程为：

$$[M]\{\ddot{U}\}+[C]\{\dot{U}\}+[K]\{U\}=\{F(t)\}$$

其中，$[M]$为质量矩阵；$[C]$为阻尼矩阵；$[K]$为刚度矩阵；$[U]$位移矩阵；$[F(t)]$为力矩阵。

1.2 模态分析与神经网络结合在损伤检测的作用

对现有结构系统进行评估并确保其在使用期间的安全性能的最重要的要求之一是损坏评估。人工神经网络（ANNs）是人脑的简化模型，并发展成为几乎所有科学和工程分支中使用的最有用的数学概念之一。由于其强大的计算能力和出色的模式识别能力，人工神经网络已被越来越多地应用于结构工程的损伤检测[1]。

模态分析和神经网络在结构损伤检测中发挥着重要作用。它们的结合可以提高损伤检测的准确性、灵敏度和效率。模态分析和神经网络在结构损伤检测中发挥着重要的作用，模态分析可以通过识别结构振动模态的变化来检测结构中的损伤。损伤通常会导致结构的振动特性发生变化，例如振动频率、振幅、模态形状等。通过比较损伤前后的模态参数，可以检测到损伤的存在和位置。

综合振动特征：模态分析可以提取结构振动的模态参数和模态形状等特征，而神经网络可以进一步学习和提取高级特征。通过将这些特征综合使用，可以更准确地描述结构的振动特性，并增强对损伤的敏感性[2]。

多尺度信息融合：结构振动信号通常包含多个频率和振幅的模态，这些模态

可能与不同的损伤类型相关。融合多尺度信息可以增强对不同损伤模式的检测能力。通过将模态分析和神经网络结合，可以在神经网络中设计多个分支或多个卷积核来处理不同尺度的振动信息，从而更全面地分析结构的振动特征。[3]利用结构的 "损伤指纹 "与主成分分析（PCA）和神经网络技术相结合来识别缺陷。

增强损伤识别能力：结构中的损伤会降低其刚度并改变其整体振动特性。因此，对振动特性变化的测量可以用来确定结构中的损伤。尽管 VBDI 具有一些优势，但由于测量误差的影响，需要使用不完整的模态振型、模态截断以及解决方案的非唯一性，大多数可用的损伤识别算法在应用于实际结构时都会失败。[4]使用基于模态能量的损伤指数来定位损伤，并使用人工神经网络技术来确定损伤的大小，即使在输入数据存在测量误差的情况下，所提出的算法在识别损坏的位置和大小方面也是相当有效的。

实时监测和预测：结合模态分析和神经网络的方法可以实现结构的实时监测和损伤预测。通过连续采集结构的振动数据并输入神经网络进行实时分析，可以及时检测和识别潜在的损伤[5]。

1.3 我们的工作

在本研究中，我们在具体仿真案例的模态分析任务中，通过在模态分析相关的数据集专门训练模型，目前通用的模态分析的模型可以表现出更好的性能。为了获得模态分析的数据集，我们考察了 Ansys APDL 的功能，并使用参数化的命令流指令实现了数据集的构建。

在本研究中，我们与以往的研究工作的不同点在于，我们花费大量时间在数据集的构建上，并且我们的数据集的输入是以参数化的形式存在。比如一个具体的均匀直杆的模态分析任务中，单个均匀直杆的输入是点的坐标位置，线由具体序号的点构成的信息，结点和单元的坐标位置以及材料和载荷和边界约束等相关信息。我们的实验说明我们的模型比传统的 FEM 算法在计算时间上的花费更少。

总结起来，我们工作的主要贡献有以下几点：

- 我们构建了一个数据量大小为 103058 样本量的模态分析数据集。
- 我们的方法输入更加突出输入数据的科学性，不再是像前人单从图像作为输入简单粗暴。
- 我们使用改进的膨胀残差卷积宽度网络模型对具体的模态分析任务进行回归预测，并且相较于 FEM 算法，我们的模型在计算性能有了进一步提高。

2. 相关研究

2.1 传统算法的模态分析应用研究现状

模态分析是工程领域中的一种关键技术，主要用于识别结构系统的自然振动模式，也就是模态。模态分析可以帮助工程师了解结构的动态行为。模态分析可以帮助我们评估一个结构或系统在各种工况下的性能。通过模态分析，我们可以确定一个系统的动态性能是否符合设计预期。如果不符合，那么模态分析可能会揭示导致问题的原因。模态分析可以用于优化设计过程。通过了解一个结构的模态，工程师可以设计出更加稳健，更能应对各种工况的结构。模态分析还可以用于预防性维护。例如，在机械系统中，模态分析可以用于检测和预防可能的机械故障，从而节省成本并增加效率。[6]基于模态参数提出了一个两阶段的破坏检测方法。[7]提出了一种新的损伤识别方法，利用测量的模态形状和自然频率来定位

和量化损伤。[8]使用 STRAND7 获得了完整结构的所有模态振型和自然频率以及假定破坏结构的前五个模态振型，可以安全和廉价地用于结构健康监测。[9]提出了一个两阶段的方法，利用二维等值分析（IGA）和有限元方法（FEM）结合优化技术对梁类结构进行损伤评估。[10]引入了一种梁类结构的损伤检测方法，不需要来自受损结构或基础模型的任何机械和几何数据；它只需要模态位移和受损梁元素的长度，就能检测损伤。模态分析还可以帮助我们了解结构在循环负载下的反应，从而进行疲劳分析和寿命预测。模态分析可以帮助我们理解噪声和振动的来源，并提供有效的控制策略。模态分析提供了对结构动态行为的深入理解，使得设计师可以做出更好的设计决策，并且在系统运行过程中更好地识别和解决问题。

2.2 人工智能在模态分析中的应用

人工智能已经在许多领域中发挥了重要作用，在模态分析的领域中，也缺少不了人工智能技术的影子。在故障检测和预测中，已经有很多研究者结合深度学习与模态分析[1]，利用深度学习从模态参数中识别出故障模式，以及预测未来的故障。[11]，[12]利用的是神经网络模型，来识别结构物的裂缝深度。[13]，[14]利用 ANN 人工神经网络输出建筑物和桥梁重要结构部件的钢梁的损坏及其位置和严重程度。[15] 利用 ANN 以及对桥梁的前三个弯曲模式分别计算了损伤指数，进而预测了结构物的破坏程度。[16]基于模态弹性（MMF）和模态应变能量（MMSE）的改进形式的损伤指数与人工神经网络（ANN）技术相结合，用于提供整体损伤评估。[17]通过一般回归神经网络（GRNN），基于模态应变能（MSE）的变化来识别钢-混凝土复合梁的损伤。[18]提出了一种使用模态试验分析模型和人工神经网络的新的损伤检测方法，输出损伤的特征。[19]，提出了一种基于 ANN 的损伤评估方法。[20]在 CNN 的输入中考虑了两种情况：第一种只使用模态应变能，第二种使用模态应变能和动态响应（加速度）的组合。显著提高结构损伤检测的正确率，并增强网络的收敛性。

ANN 被用来将 FRF 数据与损伤特征联系起来，提出的方法在处理使用 FRF 进行损伤检测的不确定性方面是有效的[21]。[22]提出了一种新的修正的损伤指标，使用透射性技术来提高局部频率响应比（LFCR），并与 ANN 相结合，实现快速预测和更高的精度。这些方法可以用于实现预防性维护，降低故障发生的风险。

3. MODAL- DRN-BL 框架

3.1 DRN

我们的核心思想是在卷积网络中保留空间分辨率用于模态分析预测。尽管渐进式降采样在分类数字或物体的标志性视图方面已经非常成功，但空间信息的丢失可能对模态分析数据的预测有害，并可能严重阻碍到涉及空间细节数据关联理解的其他任务。模态分析数据往往包含许多参数化内容，这些参数化内容的身份和相对构型对于理解场域非常重要。例如，当模态分析数据的网格划分参数化数据过大时 (例如,一个琴弦的固有频率)。在这些情况下，网格数据的响应可能会抑制来自感兴趣目标的信号。更糟糕的是，如果模态分析数据的参数化信息由于降采样而丢失，那么在训练过程中恢复的希望很小。然而，如果我们在整个模型中保持较高的空间分辨率，并提供密集覆盖输入场的输出信号，反向传播可以学习保存关于较小和不太显著对象的重要信息。[23]

我们构建的出发点是[24]提出的网络架构的集合。这些架构均由 5 组卷积层组成。每组中的第一层通过跨行进行降采样：即卷积滤波器只在偶数行和偶数列

进行评估。设每一组层用M^l表示，$l = 1, \ldots, 5$，用M_i^l表示第l组的第i层。为了简单起见，考虑一个理想化的模型，其中每一层由单个特征矩阵组成：扩展到多个特征矩阵是简单的。设f_i^l是与层M_i^l相关的滤子。在模型中，M_i^l的输出为:

$$(M_i^l * f_i^l)(p) = \sum_{a+b=p} M_i^l(a) f_i^l(b)$$

式中：p的定义域为M_i^l中的特征矩阵。

在网络的较高层增加分辨率的一个比较直接的方法是简单地从一些内部层去除子采样。这确实提高了下游的分辨率，但有一个有害的副作用，它抵消了好处：去除子采样相应地减少了后续层的感受野。[23]为此，我们使用空洞卷积[25]来增加高层的感受野，以补偿去除子采样引起的感受野的减少。其效果是扩张层中的单元与原始模型中的对应单元具有相同的感受野。

我们重点关注最后两组卷积层：M^4和M^5。在我们只是将M_1^4的输出分辨率提高了一倍而不影响其单元的感受野。然而，后续层都受到了影响：它们的感受野在每个维度上都减少了 2 倍。因此，我们将这些层中的卷积算子替换为 2-膨胀卷积[25]：

$$(M_i^4 *_2 f_i^4)(p) = \sum_{a+2b=p} M_i^4(a) f_i^4(b)$$

对所有$i \geq 2$.对M_1^5应用同样的变换：

$$(M_i^5 *_2 f_i^5)(p) = \sum_{a+2b=p} M_i^5(a) f_i^5(b)$$

M^5中的后续层遵循两个已经消除的跨层。跨步的消除使他们的感受野在每个维度上减少了 4 倍。它们的卷积需要扩大 4 倍才能弥补损失：

$$(M_i^5 *_2 f_i^5)(p) = \sum_{a+4b=p} M_i^5(a) f_i^5(b)$$

对所有$i \geq 2$.最后，与原始架构一样，M^5之后进行全局平均池化，将输出的特征映射为一个向量，并进行 1 × 1 卷积，将该向量映射为包含所有类预测得分的向量。MODAL- DRN 如图 1。

MODAL- DRN 对输入降采样 8 倍。例如，当输入分辨率为 108×16 时，一个 MODAL- DRN 中 M5 的输出为 1×10。因此，全局平均池化会多取2^4倍的值，这可以帮助 MODAL- DRN 预测模态分析数据中那些出现较少的参数化信息，并将这些对象考虑到预测中。

3.2 BL

宽度学习拥有高度可扩展性。通过增加 BLU 的数量，可以构建具有大规模节点的宽度模型，从而增加模型的学习能力和表达能力[26]。同时，宽度学习还可以有效处理高维稀疏数据，适用于各种任务，包括分类、回归、聚类等。

在 MODAL- DRN 对特征矩阵训练后，将结果输入到宽度学习的网络中，在

此次模态分析的回归任务中输出结果要求为 1×10 的数据类型。将 MODAL-DRN 的输出结果输入k组节点数为q的特征组可转换得：

$$Z_i = \sigma(XW_{zi} + \beta_{zi}) \in R^{N \times q}, i = 1,2,\dots,k$$

其中，X为膨胀卷积网络的输出，$\sigma(\cdot)$为线性激活函数，W_{zi}和β_{zi}分别表示特征层得权重矩阵和偏置矩阵,N 为样本数量。将k组Z_i拼接的Z^k经过增强层的非线性映射，增强组E_j可表述为：

$$E_j = \tau\left(Z^k W_{ej} + \beta_{ej}\right) \in R^{N \times r}, j = 1,2,\dots,m$$

其中，$\tau(\cdot)$为非线性激活函数，r是每个增强组的节点数，W_{ej}和β_{ej}分别表示增强层的权重矩阵和偏置矩阵。m组增强节点输出的结果拼接为E^m，则 BL 的最终输出可描述为：

$$\hat{Y} = [Z^k, E^m] \cdot W = AW$$

由于$\{W_{zi}, \beta_{zi}\}_{i=1}^{k}$和$\{W_{ej}, \beta_{ej}\}_{j=1}^{m}$是随机产生后的固定参数，模型的优化问题转变为优化矩阵 W，优化目标是使得预测值$\hat{Y}$与实际值Y更接近，优化问题的损失采用$Huber\ Loss$进行求解[27]。

我们的模型框架见图 1。

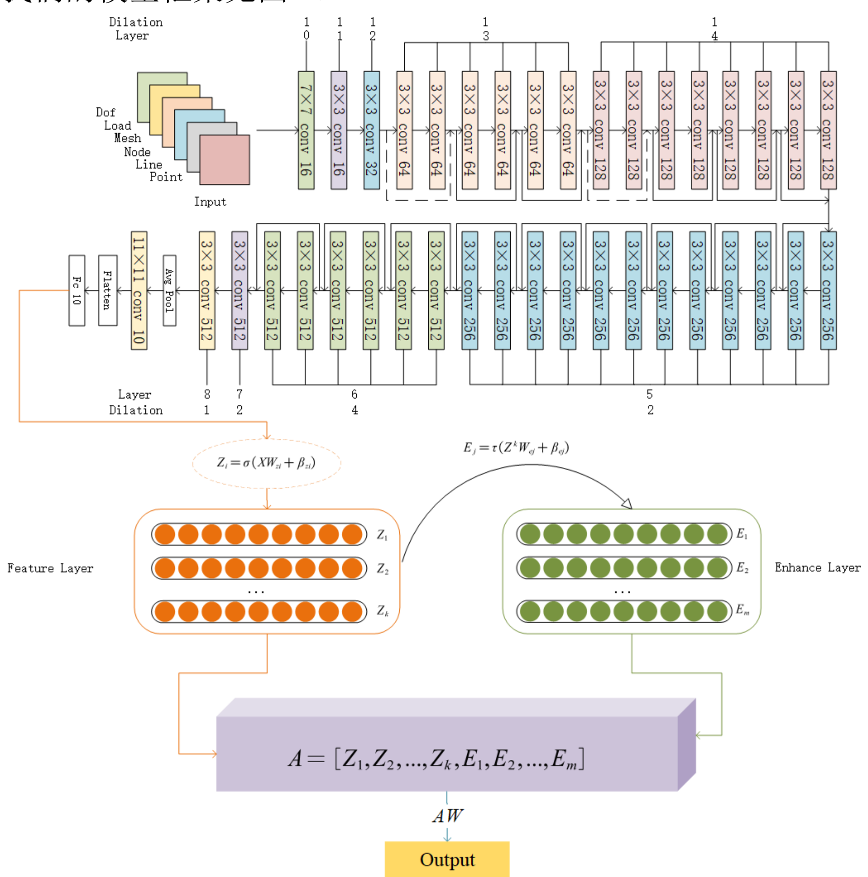


图 1 MODAL-DRN-D-BL-38 模型框架，每个矩形是一个 Conv - BN - ReLU 组(11×11 conv 10 除外)，其编号指定该层的滤波器大小和通道数。其中 Layer2、Layer3、Layer4 中的下采样步长为 2，其余均为 1。网络被划分为层次，使得给

定层次内的所有层具有相同的扩张性和空间分辨率。

4. 实验与分析

4.1 数据集

在人工智能领域中，大规模的数据收集是对具体任务验证有效性理解算法的关键资源。然而，由于收集大量模态分析案例的数据是计算和劳动密集型的，没有公开可用的包含大量 CAE 的数据集。为了支持我们的研究并提供潜在的研究方向，我们构建了一个关于多种案例类别的模态分析的数据集。

构建数据集的过程可以分为三个步骤。（1）CAD 几何建模；（2）网格生成和变形；（3）数值模拟。

我们构造的数据集模型样本总量为103058，其中模型类型涵盖多种模态分析案例。为了构造如此庞大的数据集，我们使用了Ansys提供的Pyansys工具包进行实验。通过将Ansys APDL Command转化为Pyansys所支持的Python编程语言。充分发挥Pyansys的优势，对工程应用以及日常生活中有关模态分析的零件出发，完成对应任务的CAE仿真。最后分别获取了每个模型的点、线、结点、网格单元、载荷、约束、仿真结果的数据，在后来的工作中我们对这些数据进行了清洗，以此来获得我们所想要的以张量形式的数据集,构造该数据集总共花费时间大约为一个月。

表1：模态分析的数据统计

仿真模型	网格数量	网格类别	张紧力大小/N	横截面积/m^2
3-D cylinder	25	高质量的网格 非正交网格 非光滑网络 质量较差的网格	20-2000	1e-6
3-D pipe	50	高质量的网格 非正交网格 非光滑网络 质量较差的网格	2000-5000	1e-4
3-D beam	50	高质量的网格 非正交网格 非光滑网络 质量较差的网格	5000-10000	1e-3

4.2 实验设置

使用 PyTorch 和内存为 48GB 的 A100 GPU 完成了所有实验。对于多个模型的训练，我们使用相同的超参数，初始化种子固定，批大小为 64。选择 AdamW 进行优化。将学习率设置为 0.01，每 30 个 epochs 衰减 10, weight-decay 为 1e-4。损失函数为$Huberloss$，epochs 设置为 90，选择 Hyperopt 自动调参。

我们选取不同的模型进行实验。选取 MODAL-DRN-D-22，MODAL-DRN-D-24，MODAL-DRN-C-26，MODAL-DRN-D-38，MODAL-DRN-D-40，MODAL-DRN-C-42，MODAL-DRN-A-50，MODAL-DRN-D-54，MODAL-DRN-D-56，

MODAL-DRN-C-58，MODAL-DRN-D-105，MODAL-DRN-D-107 多个网络层数不同的模型以及增加 BL 模块的对应模型在模态分析数据集进行了实验。

损失函数：参考文献[27]，*Huber*：Huber Loss 是一种介于均方误差(Mean Squared Error, MSE)和平均绝对误差(Mean Absolute Error, MAE)之间的损失函数。相比于 MAE 和 MSE，*Huber Loss*具有以下优势：鲁棒性：*Huber Loss*对于离群值或异常样本具有一定的鲁棒性。相比于*MSE*，它对异常值的敏感度较低，可以减少异常值对模型的影响。这使得*Huber Loss*在面对存在离群值的数据时表现更好。渐进平滑性：*Huber Loss*在误差较小时采用平方误差的形式，对误差较大时采用绝对误差的形式。这种渐进平滑性的特点使得*Huber Loss*能够在保留*MSE*的良好拟合能力的同时，减小了*MAE*对于离群值的敏感度。二阶可导性：与*MAE*不同，*Huber Loss*是连续可导的损失函数。这使得在使用梯度下降等基于梯度的优化算法进行模型训练时更加方便。参数可调性：*Huber Loss*具有一个额外的超参数δ，用于控制平方误差和绝对误差之间的平衡点。通过调整δ的值，可以灵活地权衡对异常值的容忍程度。当δ较小时，*Huber Loss*接近于*MSE*；当δ较大时，*Huber Loss*接近于*MAE*。这使得*Huber Loss*在实际应用中具有更大的灵活性。具体可见：

$$L_\delta\big(y,f(x)\big)=\begin{cases}\frac{1}{2}\big(y-f(x)\big)^2, if\ |y-f(x)|\le\delta\\ \delta|y-f(x)|-\frac{1}{2}\delta^2, if\ |y-f(x)|>\delta\end{cases}$$

其中y为真实值，$f(x)$为预测值，δ为*Huber Loss*的参数。

$$\delta\begin{cases}\delta\sim 0, & Huber\ Loss\rightarrow MAE\\ \delta\sim\infty, & Huber\ Loss\rightarrow MSE\end{cases}$$

如果$|y-f(x)|\le\delta$时，梯度逐渐减小保证模型更精确地得到全局最优值；如果$|y-f(x)|>\delta$时，梯度近似δ保证模型以较快的速度更新参数。

4.3 实验分析与结果

1. 评价指标

参考度量标准，我们基于*MAE*和决定系数R^2进行实验。

MAE：*MAE*(Mean Absolute Error)是一种常用的回归模型评估指标，用于衡量模型预测结果与实际观测值之间的平均绝对误差。

对于一个回归模型，它的预测值为 y_{pred}，实际观测值为y_{true}，那么*MAE*可以通过以下公式计算：

$$MAE=\left(\frac{1}{n}\right)*\Sigma\left|y_{true}-y_{pred}\right|$$

其中，n是样本的数量，Σ表示对所有样本求和，$|.|$表示取绝对值。

MAE 衡量了模型的平均预测误差的大小，它的值越小表示模型的预测越准确。与其他回归评估指标（如 *MSE*、*RMSE* 等）相比，*MAE* 对异常值的敏感性较低，因为它使用了绝对值，而不是平方。

R^2：决定系数（R^2）是评估回归模型拟合优度的常用指标。R^2 决定系数的取值范围在 0 到 1 之间，越接近 1 表示模型对观测数据的拟合程度越好，越接近 0 表示拟合程度较差。这使得R^2决定系数非常直观，易于理解和解释。R^2 决定系数提供了一种对回归模型的整体表现进行评估的方式。它通过比较总平方

和和残差平方和的比值，反映了模型能够解释的因变量的方差比例。R^2决定系数可以用于比较不同模型之间的拟合优度。通过比较不同模型的 R^2 值，可以确定哪个模型更好地拟合了数据。在多元线性回归中：

$$R^2 = \frac{SSR}{SST} = \frac{\sum(\hat{y_i} - \bar{y})^2}{\sum(y_i - \bar{y})^2}$$

其中，y_i是数据集中第i个观测值（真实值）。$\hat{y_i}$是对应于第 i 个自变量的因变量的模型预测值。$\bar{y}$是因变量（或目标变量）的平均值。

$Time$: 在 CAE（计算机辅助工程）仿真过程中，消耗的时间是一个重要的指标。时间消耗在 CAE 仿真中具有重要的意义，可以用于计算资源评估、工作流程规划、模型复杂度评估、可行性研究以及结果验证和验证。对于有效管理和优化仿真过程，了解和合理利用时间消耗是至关重要的。时间消耗可以用于规划仿真工作流程和进度安排。了解每个仿真步骤的时间需求可以帮助确定任务的优先级、调整工作计划，并确保仿真完成的时间符合项目要求。时间消耗可以用于评估仿真结果的准确性和稳定性。如果仿真时间很短，可能需要进一步验证和验证结果，以确保其可靠性和精确性。

2. 实验结果

表 2 中列出了不同模型在该数据集上的表现，包括模型名称、MAE和消耗的时间（以分钟为单位）, FEM：该行表示基准模型 FEM 的实验结果, FEM 是传统的模态分析方法，我们花费将近上万分钟的时间去对该数据集上的仿真模型进行求解。尽管表 2 中 FEM 算法的MAE我们无从得知，因为 FEM 算法本身也是一种数值解，仿真模型的解析解理论上是存在的，但是以目前的手段我们还是暂时无法得知。假设我们以 FEM 算法求解的结果为真值，但是对比一下其他 MODAL-DRN 模型和 MODAL-DRN-BL 模型与 FEM 算法的MAE和$Time$，我们认为有理由 MODAL-DRN 模型和 MODAL-DRN-BL 模型在模态分析数据集的性能是远远优于 FEM 算法的。在 CAE 仿真过程中，消耗的时间是一个重要的指标。时间消耗在 CAE 仿真中具有重要的意义，可以用于计算资源评估、工作流程规划、模型复杂度评估、可行性研究以及结果验证和验证。更进一步的，我们可以从表 2、图 2-图 5 中得知，在众多 MODAL-DRN 和 MODAL-DRN-BL 模型中，MODAL-DRN-A-BL-50 的表现效果是最佳的，其结果可能离不开 MODAL-DRN-A-BL-50 中的网络层数的设计，我们可以看到在 MODAL-DRN 系列中最优模型是 MODAL-DRN-D-38，然而增加 BL 模块后所有实验数据对比下最优的是 MODAL-DRN-A-BL-50。

表2：在模态分析数据集上的实验结果

模型	MAE	$Time(s)$	R^2
FEM	-	1,296,000	-
MODAL-DRN-D-22	9.09	5.84	0.99994
MODAL-DRN-D-BL-22	12.52	6.52	-
MODAL-DRN-D-24	8.21	6.29	1.0
MODAL-DRN-D-BL-24	158.49	7.36	-
MODAL-DRN-C-26	4.92	**4.26**	1.0
MODAL-DRN-C-BL-26	6.11	4.99	-
MODAL-DRN-D-38	1.68	5.74	0.99999

模型	MAE	$Time(s)$	R^2
MODAL-DRN-D-BL-38	2.94	6.32	-
MODAL-DRN-D-40	17.07	5.08	0.99344
MODAL-DRN-D-BL-40	207.13	5.65	-
MODAL-DRN-C-42	4.46	5.60	0.99961
MODAL-DRN-C-BL-42	11.44	5.91	-
MODAL-DRN-A-50	7.11	5.05	0.98318
MODAL-DRN-A-BL-50	**1.49**	5.79	-
MODAL-DRN-D-54	32.91	7.68	0.99945
MODAL-DRN-D-BL-54	24.88	8.29	-
MODAL-DRN-D-56	44.43	9.17	0.99986
MODAL-DRN-D-BL-56	-	-	-
MODAL-DRN-C-58	5.92	6.62	0.99159
MODAL-DRN-C-BL-58	28.09	7.34	-
MODAL-DRN-D-105	16.35	8.59	0.99950
MODAL-DRN-D-BL-105	57.15	9.27	-
MODAL-DRN-D-107	7.77	8.71	0.99989
MODAL-DRN-D-BL-107	61.14	9.63	-

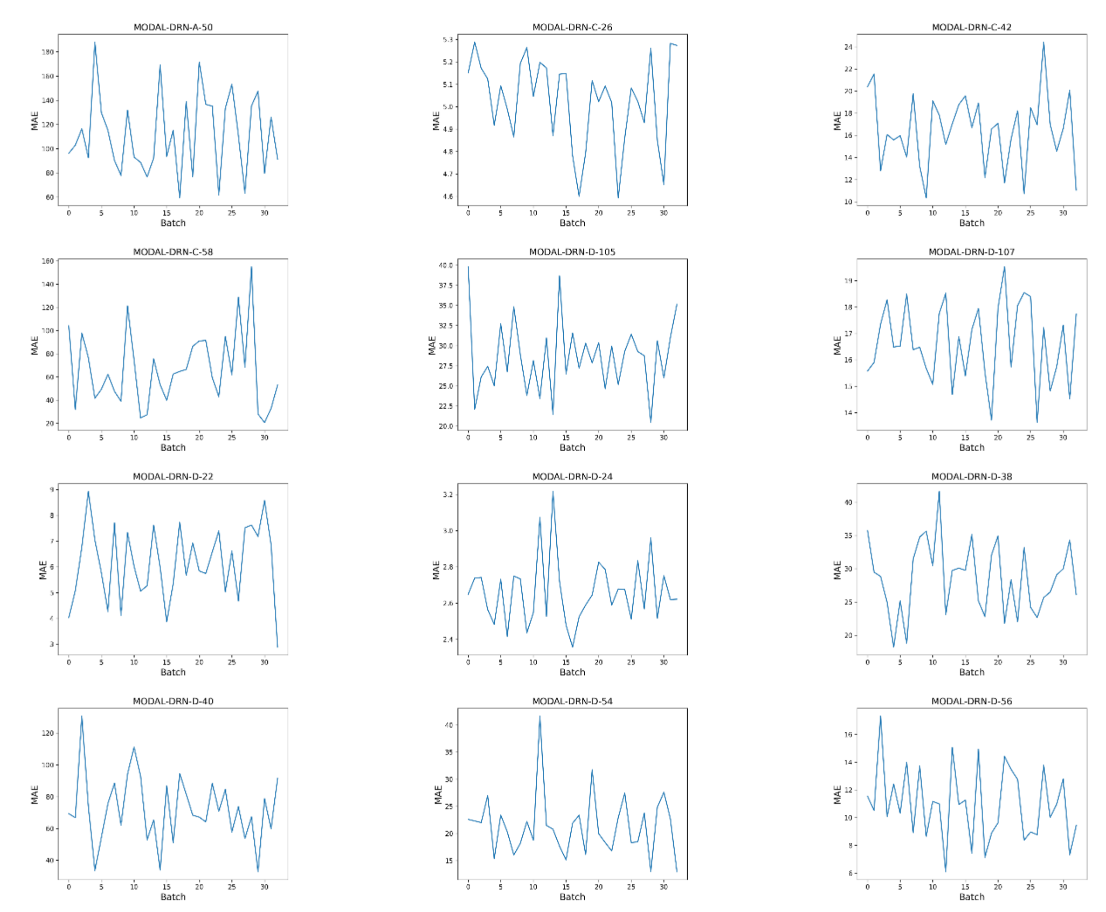


图 2 MODAL-DRN-D-22，MODAL-DRN-D-24，MODAL-DRN-C-26，MODAL-DRN-D-38，MODAL-DRN-D-40，MODAL-DRN-C-42，MODAL-DRN-A-50，MODAL-DRN-D-54，MODAL-DRN-D-56，MODAL-DRN-C-58，MODAL-DRN-D-105，MODAL-DRN-D-107 在模态分析数据集上的MAE实验结



果

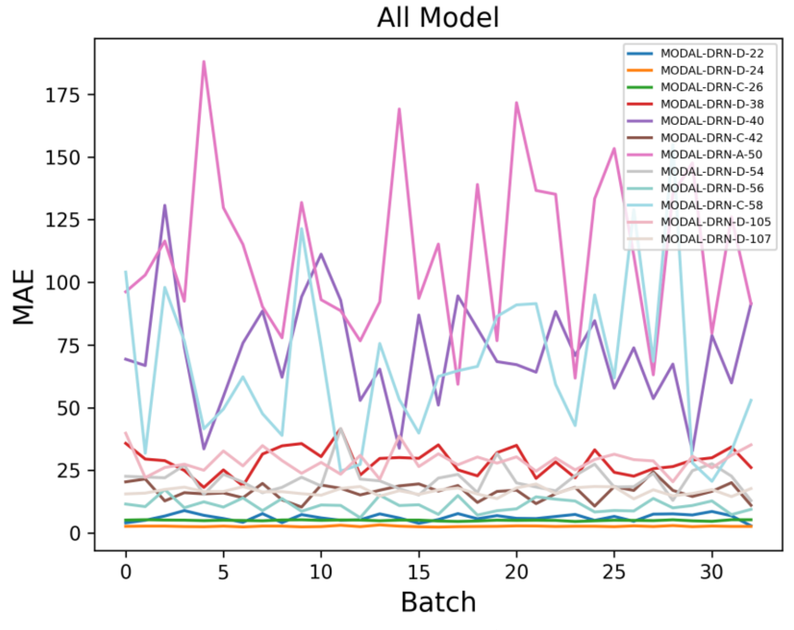


图 3 MODAL-DRN 各不同层数的模型在MAE上的对比图

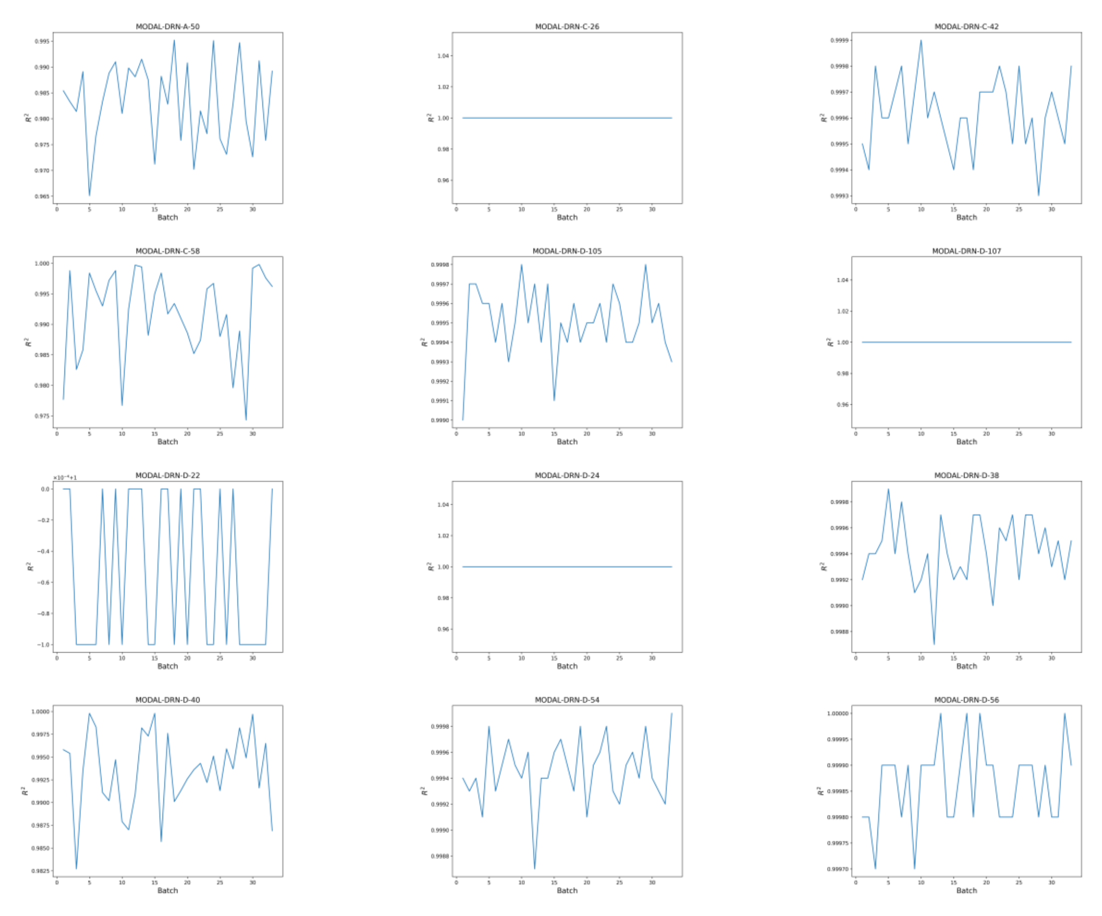


图 4 MODAL-DRN-D-22，MODAL-DRN-D-24，MODAL-DRN-C-26，MODAL-DRN-D-38，MODAL-DRN-D-40，MODAL-DRN-C-42，MODAL-DRN-A-50，MODAL-DRN-D-54，MODAL-DRN-D-56，MODAL-DRN-C-58，MODAL-DRN-D-105，MODAL-DRN-D-107 在模态分析数据集上的R^2决定系数

实验结果

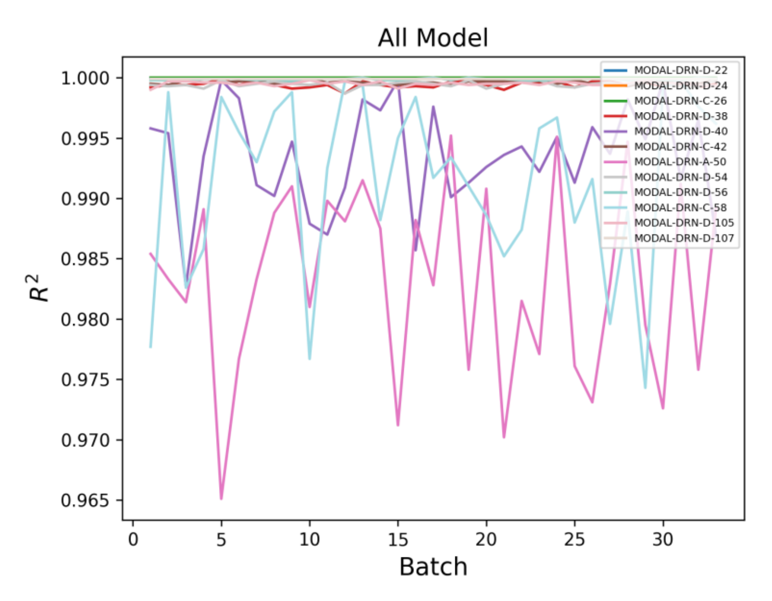


图 5 MODAL-DRN 各不同层数的模型在R^2上的对比图

3. 实验分析

我们尝试了融合几种不同的模型，包括 ViT 模型[28]、GAN[29]以及 RNN 和 LSTM[30]模型来处理模态分析数据集。然而，我发现在这些模型上的实验效果并不理想。模态分析数据集可能具有复杂的结构和特征，对于这些复杂性，这些模型可能无法很好地进行建模和学习。在我们尝试的各种模型中，MODAL-DRN 模型和 MODAL-DRN-BL 模型表现出了良好的实验效果。改进后的 MODAL-DRN 模型和 MODAL-DRN-BL 模型，具有较强的非线性建模能力和良好的特征提取能力。它们通过引入残差连接和深度的网络结构，最重要的是保持较高的空间分辨率，并提供密集覆盖输入场的输出信号，感受野的扩大极大的捕获了特征矩阵的有关信息，避免了其他模型所存在梯度爆炸问题，从而提升了模型的性能。

在模态分析数据集上，MODAL-DRN 模型和 MODAL-DRN-BL 模型可能更适合捕捉复杂的模式和特征，并能够更好地学习数据中的关键信息。它可能更有效地利用了数据集中的结构和上下文信息，从而提高了模型的预测能力和泛化能力。捕捉长距离依赖关系：在模态分析中，结构振动通常涉及到长距离的依赖关系。传统的卷积操作在提取振动特征时可能受到局部感受野范围的限制，无法充分捕捉到结构中的长程依赖关系。而膨胀残差卷积通过扩张卷积操作，能够有效扩展感受野范围，捕捉到更远距离的振动信息。这有助于提高模态分析的精度和准确性。

保持空间分辨率：模态分析通常需要对结构的局部振动模态进行分析和识别。传统的卷积操作在提高感受野范围时，通常会引入池化操作或增加卷积核尺寸，导致空间分辨率的降低。而膨胀残差卷积通过调整扩张率来实现感受野的扩张，同时保持输入和输出的空间尺寸相同，不会引起分辨率的损失。这对于保留结构的局部细节和辨识特定振动模态非常重要。

多尺度信息融合：膨胀残差卷积可通过设置不同的扩张率，实现多尺度信息的融合。在模态分析中，结构振动通常包含多个频率和振幅的振动模态。通过并行或串联多个膨胀残差卷积层，可以有效地融合不同尺度的振动信息，提高模态

分析的鲁棒性和全局感知能力。

减少参数和计算量：膨胀残差卷积相较于传统的卷积操作具有参数效率和计算效率的优势。在模态分析中，大规模结构或复杂系统的振动分析通常需要处理大量的数据和复杂的计算。采用膨胀残差卷积可以降低网络的参数量和计算复杂度，减轻计算负担，提高分析的效率。

高度可扩展性：宽度学习具有高度可扩展性，可以通过增加 BLU 的数量来增加模型的宽度。这样做可以增加模型的学习能力和表达能力，从而更好地捕捉模态分析数据中的复杂关系和特征。

MODAL-DRN-A-BL-50 模型可能采用了一种更加适合该问题的网络结构。网络结构的设计可以影响模型的学习能力和表示能力，从而在所有的 MODAL-DRN 模型和 MODAL-DRN-BL 模型系列中表现出最佳的效果。

5. 消融研究

根据表 3 中的实验结果，可以看出去除膨胀卷积对于模型的性能产生了影响。Resnet-22[24]对比 MODAL-DRN-D-22 的MAE误差增加了 3.48，同时预测时间也增加了 0.96。Resnet-26 对比 MODAL-DRN-C-26 的MAE误差增加了惊人的 845.9，预测时间也随之增加了 25.44。综合对比去除膨胀感受野的模型和 MODAL-DRN 模型，增加膨胀卷积模块提高了模型的预测准确性并减少训练时间。这表明膨胀卷积在这些实验中去除了一定的误差，并且去除膨胀卷积会降低模型的性能。

表3：去除膨胀感受野后的模态分析实验结果

模型	MAE	$Time(s)$	R^2
Resnet-22	12.57	6.80	0.99998
MODAL-DRN-D-22	**9.09(-3.48)**	**5.84(-0.96)**	0.99994
Resnet-26	850.82	29.70	0.85747
MODAL-DRN-C-26	**4.92(-845.9)**	**4.26(-25.44)**	1.0
Resnet-38	15.78	9.19	0.99999
MODAL-DRN-D-38	**1.68(-14.1)**	**5.74(-3.45)**	0.99999
Resnet-42	223.20	38.53	0.98556
MODAL-DRN-C-42	**3.96(-219.24)**	**5.60(-32.93)**	0.99961

根据表 4 和表 2 中的实验结果，可以看出模型以 50 层为分界岭，在浅层网络和深层网络中，增加 BL 模块对于预测结果的改良并没有起到多大作用，在 50 层左右的网络中，增加 BL 模块的网络预测结果对比 MODAL-DRN 系列的最优预测结果更优，为 MODAL-DRN-A-BL-50 的 1.49。对比表 3 的结果我们也可以得出增加 BL 模块的网络肯定是优胜于 Resnet 网络架构的。综上所述，我们可以发现增加 BL 模块对于模态分析实验结果的改良是有一定的作用的。

表4：去除宽度学习模块后的模态分析实验结果

模型	MAE	$Time(s)$	R^2
MODAL-DRN-C-42	**4.46(-6.98)**	**5.60(-0.31)**	0.99961
MODAL-DRN-C-BL-42	11.44	5.91	-
MODAL-DRN-A-50	7.11	**5.05(-0.74)**	0.98318
MODAL-DRN-A-BL-50	**1.49(-5.62)**	5.79	-
MODAL-DRN-D-54	32.91	**7.68(-0.61)**	0.99945
MODAL-DRN-D-BL-54	**24.88(-8.03)**	8.29	-

模型	MAE	$Time(s)$	R^2
MODAL-DRN-D-107	**7.77(-53.37)**	**8.71(-0.92)**	0.99989
MODAL-DRN-D-BL-107	61.14	9.63	-

6. 结论

从一个新的视角出发，我们为模态分析任务提供了一个膨胀残差卷积宽度网络的框架，科学地直接将案例参数化的信息作为输入数据。此外，我们的保持较高的空间分辨率，并提供密集覆盖输入场的输出信号，该模型利用膨胀残差卷积感受野的扩张以及宽度网络的高度可扩展性，能够更加优秀地学习特征矩阵的有关信息，不断地去降低损失，迭代至在预测性能能与 FEM 有限元算法相当。同时，我们的模型相较于有限元算法将会在计算速度有了质上的飞跃。根据实验结果，我们的模型在模态分析任务中显著优于有限元算法。未来将继续探索更适合随着结构的使用和环境的变化，结构的模态特性发生可能的变化后，我们的模型也能够准确预测结果，并更新模态分析模型。

参考文献：

[1] Hakim S, Razak H A. Modal parameters based structural damage detection using artificial neural networks-a review[J]. Smart Structures and Systems, 2014, 14(2): 159-189.

[2] Bakhary N, Hao H, Deeks A J. Damage detection using artificial neural network with consideration of uncertainties[J]. Engineering Structures, 2007, 29(11): 2806-2815.

[3] Dackermann U, Li J, Samali B. Dynamic-based damage identification using neural network ensembles and damage index method[J]. Advances in Structural Engineering, 2010, 13(6): 1001-1016.

[4] Xu H, Humar J. Damage detection in a girder bridge by artificial neural network technique[J]. Computer‐Aided Civil and Infrastructure Engineering, 2006, 21(6): 450-464.

[5] Meruane V, Mahu J. Real-time structural damage assessment using artificial neural networks and antiresonant frequencies[J]. Shock and Vibration, 2014, 2014.

[6] Ghasemi M R, Nobahari M, Shabakhty N. Enhanced optimization-based structural damage detection method using modal strain energy and modal frequencies[J]. Engineering with Computers, 2018, 34: 637-647.

[7] Nguyen K-D, Chan T H, Thambiratnam D P. Structural damage identification based on change in geometric modal strain energy–eigenvalue ratio[J]. Smart Materials and Structures, 2016, 25(7): 075032.

[8] Moradi Pour P, Chan T, Gallage C. An improved modal strain energy method for structural damage detection, 2D simulation[J]. Structural Engineering and Mechanics, 2015, 54(1): 105-119.

[9] Khatir S, Wahab M A, Boutchicha D, et al. Structural health monitoring using modal strain energy damage indicator coupled with teaching-learning-based optimization algorithm and isogeometric analysis[J]. Journal of Sound and Vibration, 2019, 448: 230-246.

[10] Pooya S M H, Massumi A. A novel damage detection method in beam-like structures based on the relation between modal kinetic energy and modal strain energy and using only damaged structure data[J]. Journal of Sound and Vibration, 2022, 530: 116943.
[11] Khatir A, Capozucca R, Khatir S, et al. Vibration-based crack prediction on a beam model using hybrid butterfly optimization algorithm with artificial neural network[J]. Frontiers of Structural and Civil Engineering, 2022: 1-14.
[12] Al Thobiani F, Khatir S, Benaissa B, et al. A hybrid PSO and Grey Wolf Optimization algorithm for static and dynamic crack identification[J]. Theoretical and applied fracture mechanics, 2022, 118: 103213.
[13] Tan Z X, Thambiratnam D, Chan T, et al. Detecting damage in steel beams using modal strain energy based damage index and Artificial Neural Network[J]. Engineering Failure Analysis, 2017, 79: 253-262.
[14] Tan Z X, Thambiratnam D P, Chan T H, et al. Damage detection in steel-concrete composite bridge using vibration characteristics and artificial neural network[J]. Structure and Infrastructure Engineering, 2020, 16(9): 1247-1261.
[15] Nick H, Aziminejad A, Hosseini M H, et al. Damage identification in steel girder bridges using modal strain energy-based damage index method and artificial neural network[J]. Engineering Failure Analysis, 2021, 119: 105010.
[16] Jayasundara N, Thambiratnam D, Chan T, et al. Damage detection and quantification in deck type arch bridges using vibration based methods and artificial neural networks[J]. Engineering Failure Analysis, 2020, 109: 104265.
[17] Sadeghi F, Yu Y, Zhu X, et al. Damage identification of steel-concrete composite beams based on modal strain energy changes through general regression neural network[J]. Engineering Structures, 2021, 244: 112824.
[18] Ghannadi P, Kourehli S S. An effective method for damage assessment based on limited measured locations in skeletal structures[J]. Advances in Structural Engineering, 2021, 24(1): 183-195.
[19] Paral A, Singha Roy D K, Samanta A K. Application of a mode shape derivative-based damage index in artificial neural network for structural damage identification in shear frame building[J]. Journal of Civil Structural Health Monitoring, 2019, 9: 411-423.
[20] Teng S, Chen G, Gong P, et al. Structural damage detection using convolutional neural networks combining strain energy and dynamic response[J]. Meccanica, 2020, 55: 945-959.
[21] Padil K H, Bakhary N, Abdulkareem M, et al. Non-probabilistic method to consider uncertainties in frequency response function for vibration-based damage detection using artificial neural network[J]. Journal of Sound and Vibration, 2020, 467: 115069.
[22] Zenzen R, Khatir S, Belaidi I, et al. A modified transmissibility indicator and Artificial Neural Network for damage identification and quantification in laminated composite structures[J]. Composite Structures, 2020, 248: 112497.
[23] Yu F, Koltun V, Funkhouser T. Dilated residual networks[C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2017: 472-480.
[24] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016: 770-778.

[25] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[J]. arXiv preprint arXiv:1511.07122, 2015.
[26] Chen C P, Liu Z. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. IEEE transactions on neural networks and learning systems, 2017, 29(1): 10-24.
[27] Huber P J. Robust estimation of a location parameter[J]. Breakthroughs in statistics: Methodology and distribution, 1992: 492-518.
[28] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J]. arXiv preprint arXiv:2010.11929, 2020.
[29] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
[30] Graves A, Graves A. Long short-term memory[J]. Supervised sequence labelling with recurrent neural networks, 2012: 37-45.

(通讯作者：阳爱民　E-mail：amyang@gdut.edu.cn)
(通讯作者：林江豪　E-mail：lin_hao@foxmail.com)

作者贡献声明*：

曾培健：提出研究思路，设计研究方案，数据的获取，进行实验，论文起草；
白期风：提供研究思路，数据的获取；
林楠铠：提供研究思路，数据的获取；
李顺：数据的获取，进行实验；
阳爱民：提供研究思路，论文起草；
林江豪：论文最终版本修订。

* 作者贡献可分为以下内容：1）研究命题的提出、设计，包括某个具体观点或方法的提出；2）研究过程的实施，例如进行试验或调查；3）数据的获取、提供与分析；4）论文起草或最终版本修订。每个研究论文可以根据自己研究活动的特点进一步详细表述作者贡献。有些研究活动可能还涉及其他研究工作和贡献，可以进一步具体表述。在有多个作者署名的论文中，在论文最后必须注明每个作者在上述四个方面中的具体贡献。